



# METODE OPTIMIZACIJE NELINEARNO PROGRAMIRANJE

Dr Tina Dašić  
Dr Miloš Stanić

Građevinski fakultet Univerziteta u Beogradu  
2014.



## UVOD

### Podela prema vrsti optimizacionog problema

1. Broj kriterijumskih funkcija
  - jednokriterijumska
  - višekriterijumska
2. Ograničenja
  - bez ograničenja
  - sa ograničenjima
    - linearna
    - nelinearna
3. Forma kriterijumske funkcije
  - linearna
  - nelinearna
    - kvadratna
    - ...
4. Domen promenljivih
  - diskretan
  - **realan**
  - mesovit

### Podela prema metodama optimizacije

1. Determinističke
  - linearno programiranje (LP)
  - kvadratno programiranje (QP)
  - kombinatorna optimizacija (grafovi)
  - **nelinearno programiranje (NLP)**
    - sa gradijentima
    - bez gradijenata
2. Stohastičke (heuristike)
  - Skup rešenja
  - Jedno rešenje

## FORMULACIJA PROBLEMA



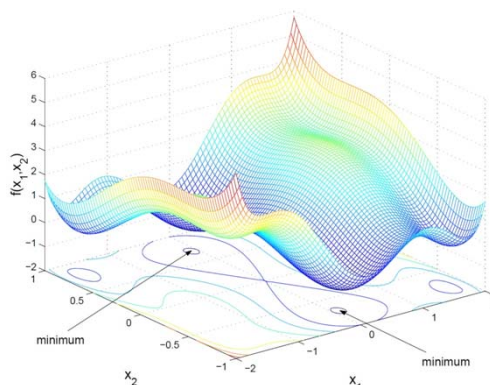
Zadatak optimizacije je pronalaženje promjenljivih pri kojima ciljna (kriterijumska) funkcija uzima ekstremnu (minimalnu ili maksimalnu) vrednost, uz ograničenja sa kojima se definiše prostor mogućih rešenja.

$$\min_{X \in R^n} f(X)$$

$$\varphi_j(X) = 0, j = 1, \dots, J$$

$$\psi_k(X) \leq 0, k = 1, \dots, K$$

$f$  kriterijumska funkcija,  
 $\varphi$  ograničenja u formi jednakosti  
 $\psi$  funkcije ograničenja u formi nejednakosti.



## FORMULACIJA PROBLEMA



Ako se radi o problemu određivanja maksimuma funkcije, on se dobija veoma jednostavnom reformulacijom problema:

$$\max f(X) = \min (-f(X))$$

Ako su kriterijumska funkcija i funkcije ograničenja linearne, radi se o zadatku linearnog programiranja.

Ukoliko funkcije ograničenja ne postoje, onda se radi o problemu bezuslovne optimizacije.

$$\min_{X \in R^n} f(X) \longrightarrow X^* = \begin{bmatrix} x_1 \\ \dots \\ x_n \end{bmatrix}$$

## FORMULACIJA PROBLEMA



Ukoliko funkcije ograničenja postoje, moguće je preformulisati optimizacioni zadatak uvođenjem kaznene funkcije  $P(X)$ .

$$\begin{array}{l} \min_{X \in \mathbb{R}^n} f(X) \\ \varphi_j(X) = 0, j = 1, \dots, J \\ \psi_k(X) \leq 0, k = 1, \dots, K \end{array} \longrightarrow \begin{array}{l} \min_{X \in \mathbb{R}^n} f^*(X) = f(X) + \lambda \cdot P(X) \\ P(X) = \sum_j [\varphi_j(X)]^2 + \sum_k [\max(0, \psi_k(X))]^2 \end{array}$$

Očigledno je da je vrednost kaznene funkcije  $P(X)=0$ , kada su sva ograničenja zadovoljena, čime je moguće optimizacioni zadatak sa ograničenjima svesti na zadatak bez ograničenja.

## Bezuslovna optimizacija - funkcija jedne promenljive




### Uslovi optimalnosti

Egzistencija rešenja - da li rešenje postoji?

**Potreban uslov:**  $f'(x) = 0$

**Dovoljan uslov:**

ako je  $x^*$  tačka u kojoj je ispunjen potreban uslov pojave lokalnog ekstrema  $f'(x^*) = 0$  i ukoliko je  $f''(x^*) > 0$ , onda je  $x^*$  tačka lokalnog minimuma.



## Bezuslovna optimizacija - funkcija jedne promenljive



### Metode zasnovane na gradijentima – Newton-ova metoda

Razvojem funkcije  $f(x)$  u Taylor-ov red dobija se:

$$f(x) = f(x_i) + f'(x_i)(x - x_i) + \frac{1}{2} f''(x_i)(x - x_i)^2 + \dots$$

Postavljanjem potrebnog uslova  $f'(x)=0$ , uz zadržavanje prva 3 člana reda, dobija se:

$$f'(x_i) + f''(x_i)(x - x_i) = 0$$

Imajući u vidu da su zadržana samo prva tri člana Tejlorovog reda, do rešenja se stiže u iteracijama:

$$x_{i+1} = x_i - \frac{f'(x_i)}{f''(x_i)}$$

## Bezuslovna optimizacija - funkcija jedne promenljive




### Metode zasnovane na gradijentima – Newton-ova metoda

$$x_{i+1} = x_i - \frac{f'(x_i)}{f''(x_i)}$$

Problem se svodi na pronalaženje nule funkcije  $f'(x)$ .

Uslovi za uspešnu primenu metode:

- poznati prvi i drugi izvod funkcije
- rezultat može zavistiti od izbora tačke od koje se počinje sa pretragom (slika a) – primer uspešne primene metode, a slika b) primer neuspešne)



## Bezuslovna optimizacija - funkcija jedne promenljive



### Metode zasnovane na gradijentima – Newton-ova metoda


$$x_{i+1} = x_i - \frac{f'(x_i)}{f''(x_i)}$$

Ako prvi ili drugi izvod funkcije nisu poznati ili ih je teško odrediti,  $f'(x_i)$  i  $f''(x_i)$  se mogu sračunati približno, primenom metode konačnih razlika:

$$f'(x_i) = \frac{f(x_i + \delta) - f(x_i - \delta)}{2\delta}$$

$$f''(x_i) = \frac{f(x_i + \delta) - 2f(x_i) + f(x_i - \delta))}{\delta^2}$$

$$x_{i+1} = x_i - \frac{\delta \cdot (f(x_i + \delta) - f(x_i - \delta))}{2 \cdot (f(x_i + \delta) - 2f(x_i) + f(x_i - \delta))}$$



## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti


Egzistencija rešenja - da li rešenje postoji?

$$\min_{X \in \mathbb{R}^n} f(X) \longrightarrow X^* = \begin{bmatrix} x_1 \\ \dots \\ x_n \end{bmatrix}$$

Gradijent funkcije:  $\nabla f(X) = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \dots \\ \frac{\partial f}{\partial x_n} \end{bmatrix}$

Potreban uslov lokalnog ekstrema:

$$\nabla f(X) = 0 \longrightarrow X^* = \begin{bmatrix} x_1 \\ \dots \\ x_n \end{bmatrix}$$



## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti


Potreban uslov lokalnog ekstrema:

$$\nabla f(X) = 0 \longrightarrow X^* = \begin{bmatrix} x_1 \\ \dots \\ x_n \end{bmatrix}$$


### Primer

$$f = x_1 \exp(-x_1^2 - x_2^2)$$

$$\nabla f = \begin{bmatrix} \partial f / \partial x_1 \\ \partial f / \partial x_2 \end{bmatrix} = \begin{bmatrix} (1 - 2x_1^2) \exp(-x_1^2 - x_2^2) \\ -2x_1 x_2 \exp(-x_1^2 - x_2^2) \end{bmatrix}$$



$$\nabla f = 0 \longrightarrow \begin{cases} x_1 = \pm 1/\sqrt{2} \\ x_2 = 0 \end{cases} \longrightarrow \begin{cases} \min f = -1/\sqrt{2}e \\ \max f = 1/\sqrt{2}e \end{cases}$$



## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti

Potreban uslov lokalnog ekstrema:  $\nabla f(X) = 0$

### Primer – metod najmanjih kvadrata


Problem pronalaženja polinoma stepena  $n$  ( $P_n$ ) sa kojim treba „fitovati“ tačke merenja  $\{(x_1, y_1), \dots, (x_m, y_m)\}$

$$P_n(x) = a_0 + a_1x + \dots + a_nx^n$$

Potrebno je odrediti koeficijente polinoma (vektor)  $a = [a_0, \dots, a_n]^T$ , koji predstavljaju minimum funkcije greške:

$$f(a) = \sum_{i=1}^m (y_i - P_n(x_i))^2 \longrightarrow \nabla f = \begin{bmatrix} \partial f / \partial a_0 \\ \dots \\ \partial f / \partial a_n \end{bmatrix} = 0$$

Dobija se sistem linearnih jednačina koji se rešava po poznatom vektoru  $a$ .



## Bezuslovna optimizacija - funkcija više promenljivih



### Primer – metod najmanjih kvadrata

Ovaj problem se može napisati i u matičnom obliku:

$$b = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_m \end{bmatrix}, \quad A = \begin{bmatrix} 1 & x_1 & \dots & x_1^n \\ 1 & x_2 & \dots & x_2^n \\ \dots & \dots & \dots & \dots \\ 1 & x_m & \dots & x_m^n \end{bmatrix}, \quad a = \begin{bmatrix} a_0 \\ a_1 \\ \dots \\ a_n \end{bmatrix}, \quad r = A \cdot a - b = \begin{bmatrix} P_n(x_1) - y_1 \\ \dots \\ P_n(x_m) - y_m \end{bmatrix}$$

gde je sa  $r$  označen vektor reziduala. Funkcija, koja predstavlja sumu kvadrata odstupanja ima oblik:

$$f(a) = r^T r = a^T A^T A a - 2b^T A a + b^T b$$

Iz potrebnog uslova optimalnosti, dobija se:

$$\nabla f(a) = 2A^T A a - 2A^T b = 0 \quad \longrightarrow \quad a = (A^T A)^{-1} A^T b$$

## Bezuslovna optimizacija - funkcija više promenljivih



### Primer – metod najmanjih kvadrata


**Primer:**

$m = 40$

Korišćeni polinomi:  
 $n = 2, 3$  i  $10$

Srednje kvadratno odstupanje:

$$err = (r^T r)/m = 0.0415, 0.0240 \text{ i } 0.0214$$



## Bezuslovna optimizacija - funkcija više promenljivih



### Primer – metod najmanjih kvadrata

Sa polinomom većeg stepena, moguće je dobiti bolje slaganje, ali to podrazumeva pojavu “oscilacija” koje najčešće nisu deo prirode fenomena.


Zbog toga se funkcija greške često predstavlja na sledeći način:

$$f(a) = r^T r + \gamma a^T a$$

gde je  $\gamma (>0)$  koeficijent kojim se penalizuju polinomi višeg stepena.

$$a = (A^T A + \gamma E)^{-1} A^T b$$

$E$  – jedinična matrica dimenzija  $(n+1)$



## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti

Potreban uslov lokalnog ekstrema:  $\nabla f(X) = 0 \longrightarrow X^* = \begin{Bmatrix} x_1 \\ \dots \\ x_n \end{Bmatrix}$

Dovoljan uslov minimuma  $f(X)$ :

Razvojem funkcije  $f(X)$  u Taylor-ov red u okolini tačke  $X^*$  i zadržavanjem samo prva tri člana:  $f(X) = f(X^*) + (\nabla f(X^*))^T (X - X^*) + \frac{1}{2} (X - X^*)^T (\nabla^2 f(X^*)) (X - X^*)$

Matrica Hessian-a:  $H(X) = \nabla^2 f(X) = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \dots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \dots & \dots & \dots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \dots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$

Ako je  $X^*$  tačka u kojoj je zadovoljen potreban uslov optimalnosti  $\nabla f(X^*) = 0$  da bi ta tačka bila minimum, potrebno je da  $f(X) > f(X^*)$  iz čega sledi dovoljan uslov minimuma funkcije više promenljivih:

$$\Delta X^T H(X^*) \Delta X > 0$$

gde je:  $\Delta X = X - X^*$



## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti

Potreban uslov lokalnog ekstrema:  $\nabla f(X) = 0 \longrightarrow X^* = \begin{Bmatrix} x_1 \\ \dots \\ x_n \end{Bmatrix}$

Dovoljan uslov minimuma funkcije više promenljivih, je da matrica Hessian-a  $H$  bude *pozitivno definitna*:

$$\Delta X^T H(X^*) \Delta X > 0$$

Po definiciji, pozitivna definitnost matrice podrazumeva da prethodni uslov bude ispunjen za bilo koji vektor  $\Delta X$ .

Kako prethodni uslov mora biti ispunjen i za svaki jedinični vektor, to znači da dijagonalni elementi matrice  $H$  moraju biti pozitivni (nije dovoljan uslov).

Postoji nekoliko načina da se proveri pozitivna definitnost matrice  $H$ .

## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti

Simetrična matrica je pozitivno definitna, ako su svi minori glavne dijagonale  $H_{ii}$  pozitivni.

#### Primer:

$$f = 4x_1^2 + 3x_2^2 + 5x_3^2 + 6x_1x_2 + x_1x_3 - 3x_1 - 2x_2 + 15:$$

Determinante glavnih minora:  $H_{11}$ ,  $H_{22}$ ,  $H_{33}$  su pozitivne, pa je matrica pozitivno definitna:

$$|H_{11}| = |8| = 8 > 0$$

$$|H_{22}| = \begin{vmatrix} 8 & 6 \\ 6 & 6 \end{vmatrix} = 8 > 0$$

$$|H_{33}| = \begin{vmatrix} 8 & 6 & 1 \\ 6 & 6 & 0 \\ 1 & 0 & 10 \end{vmatrix} = 114 > 0$$

$$H(X) = \begin{bmatrix} \partial^2 f / \partial x_1^2 & \partial^2 f / \partial x_1 \partial x_2 & \partial^2 f / \partial x_1 \partial x_3 \\ \partial^2 f / \partial x_1 \partial x_2 & \partial^2 f / \partial x_2^2 & \partial^2 f / \partial x_2 \partial x_3 \\ \partial^2 f / \partial x_1 \partial x_3 & \partial^2 f / \partial x_2 \partial x_3 & \partial^2 f / \partial x_3^2 \end{bmatrix} = \begin{bmatrix} 8 & 6 & 1 \\ 6 & 6 & 0 \\ 1 & 0 & 10 \end{bmatrix}$$

## Bezuslovna optimizacija - funkcija više promenljivih



### Uslovi optimalnosti

Drugi način za proveru pozitivne definitnosti matrice je preko sopstvenih vrednosti.

$$HX = \lambda X$$

$$(H - \lambda E)X = 0$$

Sopstvene vrednosti  $\lambda$  se dobijaju iz uslova da netrivialna rešenja sistema postoje kada je ispunjen uslov:

$$|H - \lambda E| = 0 \rightarrow \lambda$$

Ako su sve sopstvene vrednosti, simetrične matrice  $H$  pozitivne, matrica je pozitivno definitna:  $X^T H X = X^T \lambda X \rightarrow \lambda = \frac{X^T H X}{X^T X} > 0$

**Primer:**

$$H = \begin{bmatrix} \alpha & \beta \\ \beta & \alpha \end{bmatrix}$$

$$|H - \lambda E| = \begin{vmatrix} \alpha - \lambda & \beta \\ \beta & \alpha - \lambda \end{vmatrix} = (\alpha - \lambda)^2 - \beta^2 = 0 \rightarrow \lambda = \alpha \pm \beta > 0$$

## Bezuslovna optimizacija - funkcija više promenljivih





### Uslovi optimalnosti

**Primer:** "Banana funkcija"  $f(x, y) = (x - 1)^2 + 100(y - x^2)^2$

Potreban uslov:

$$\nabla f = \begin{bmatrix} 2(x - 1) - 400x(y - x^2) \\ 200(y - x^2) \end{bmatrix} = 0 \rightarrow x^* = 1, y^* = 1$$



Dovoljan uslov:

$$H = \begin{bmatrix} 2 + 1200x^2 - 400y & -400x \\ -400x & 200 \end{bmatrix} \rightarrow H(1, 1) = \begin{bmatrix} 802 & -400 \\ -400 & 200 \end{bmatrix}$$

## Bezuslovna optimizacija - funkcija više promenljivih



Metode zasnovane na gradijentima

Metoda Newton-a

$$f(X) = f(X_i) + (\nabla f(X_i))^T (X - X_i) + \frac{1}{2} (X - X_i)^T (\nabla^2 f(X_i)) (X - X_i)$$

Iz uslova da je prvi izvod funkcije  $f(X)$  jednak 0 dobija se:

$$\nabla f(X_i) + (\nabla^2 f(X_i))(X - X_i) = 0$$

Do rešenja se dolazi u iteracijama:

$$X_{i+1} = X_i - H(X_i)^{-1} \nabla f(X_i)$$

Prednost ove metode je brzina konvergencije. Kod kvadratnih funkcija, rešenje se dobija u jednom koraku.

Nedostatak je, što je potrebno računati matricu  $H$  i njenu inverznu vrednost u svakoj iteraciji proračuna. Osim toga proračun je veoma osetljiv na izbor početne tačke.

## Bezuslovna optimizacija - funkcija više promenljivih



Metode zasnovane na gradijentima

Metoda Newton-a

Primer:

$$f = (x_1 - 3)^2 + 3(x_2 - 1)^2 + 2$$

Originalna Newton-ova metoda zahteva poznavanje prvog i drugog izvoda funkcije:

$$\nabla f = \begin{bmatrix} 2(x_1 - 3) \\ 6(x_2 - 1) \end{bmatrix} \quad H = \begin{bmatrix} 2 & 0 \\ 0 & 6 \end{bmatrix}$$

Usvaja se početna tačka:  $X_0 = [0, 0]^T$

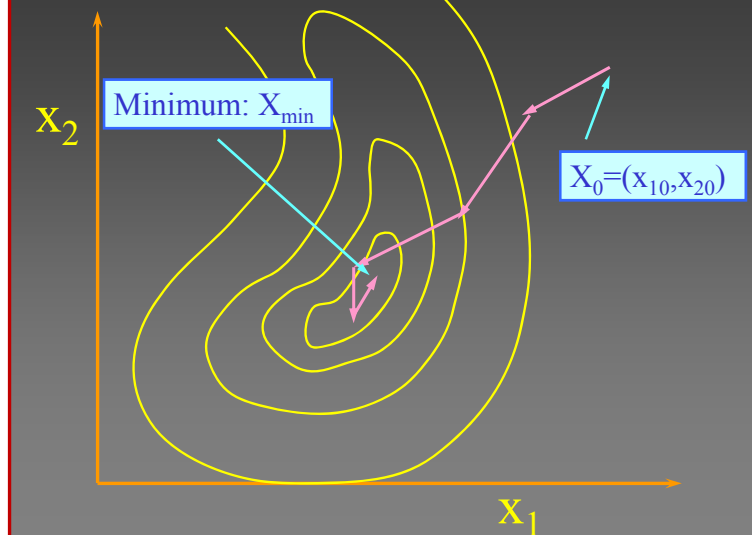
$$X_1 = X_0 - H^{-1} \nabla f(X_0) = \begin{bmatrix} 0 \\ 0 \end{bmatrix} - \begin{bmatrix} 1/2 & 0 \\ 0 & 1/6 \end{bmatrix} \cdot \begin{bmatrix} -6 \\ -6 \end{bmatrix} = \begin{bmatrix} 3 \\ 1 \end{bmatrix}$$

U tački  $X_1 = [3, 1]^T$ , ispunjeni su i potreban i dovoljan uslov, pa je ta tačka lokalni minimum.

## Bezuslovna optimizacija - funkcija više promenljivih



Metode zasnovane na gradijentima



## Bezuslovna optimizacija - funkcija više promenljivih



Metode zasnovane na gradijentima

**Metod najstrmijih gradijenata – Cauchy-jev metod**

Kod metode najstrmijih gradijenata, pronalazi se najmanja vrednost funkcije u pravcu vektora  $\Delta s$ .

$$f(X_i + \Delta s) = f(X_i) + (\nabla f(X_i))^T \Delta s$$

Kako je ideja da se nadje manja vrednost funkcije to mora biti ispunjen uslov:

$$f(X_i + \Delta s) - f(X_i) = (\nabla f(X_i))^T \Delta s < 0$$

Scalarni proizvod dva vektora je minimalan kada su oni paralelni i suprotnim smerovima, pa  $\Delta s$  treba računati iz uslova:  $\Delta s = -\alpha \nabla f(X_i)$  gde je  $\alpha > 0$  veličina koraka propagacije u pravcu  $\Delta s$ .

## Bezuslovna optimizacija - funkcija više promenljivih



### Metode zasnovane na gradijentima

#### Metod naj strmijih gradijenata – Cauchy-jev metod

$$f(X_{i+1}) = f(X_i) - \alpha(\nabla f(X_i))^T \nabla f(X_i)$$

Vrednost  $\alpha$ , nije proizvoljna. Mala vrednost, bi značila sporu konvergenciju, a prevelika bi mogla dovesti da se premaši cilj i ode dalje od lokalnog minimuma.

Korak  $\alpha$  se menja u svakoj iteraciji proračuna i dobija se iz uslova minimumu funkcije:

$$\phi(\alpha_i) = f(X_{i+1}) = f(X_i - \alpha_i \nabla f(X_i))$$

$$\frac{d\phi(\alpha_i)}{d\alpha_i} = 0 \rightarrow \alpha_i$$

$$\text{Nova vrednost vektora: } X_{i+1} = X_i - \alpha_i \nabla f(X_i)$$

Ako se Cauchy-jev metod uporedi sa metodom Newton-a, očigledno je da je matrica  $H$  pojednostavljena i da se računa:  $H(X_i)^{-1} = \alpha_i E$

## Bezuslovna optimizacija - funkcija više promenljivih



### Metode zasnovane na gradijentima

#### Metod naj strmijih gradijenata – Cauchy-jev metod

Primer:  $f = 10x_1^2 + 5x_1x_2 + 10(x_2 - 3)^2$ , početna tačka je  $X_0 = [10, 15]^T$

$$\text{Prva iteracija: } X_1 = X_0 - \alpha_0 \nabla f(X_0) = \begin{bmatrix} 10 \\ 15 \end{bmatrix} - \alpha_0 \begin{bmatrix} 275 \\ 290 \end{bmatrix}$$

Korak propagacije  $\alpha_0$  se nalazi iz uslova minimuma funkcije  $f$  u pravcu gradijenta u tački  $X_0$ :

$$\phi(\alpha_0) = 10(10 - 275\alpha_0)^2 + 5(10 - 275\alpha_0)(15 - 290\alpha_0) + 10(15 - 290\alpha_0)^2$$

$$\frac{d\phi(\alpha_0)}{d\alpha_0} = -159725 + 3992000\alpha_0 = 0 \rightarrow \alpha_0 = 0.04001 \rightarrow X_1 = [-1.0027, 3.3971]^T$$

$$\text{Druga iteracija: } \nabla f(X_1) = \begin{bmatrix} -3.078 \\ 2.919 \end{bmatrix}, X_2 = X_1 - \alpha_1 \begin{bmatrix} -3.078 \\ 2.919 \end{bmatrix}$$

Iz minimuma funkcije  $\phi(\alpha_1)$ , dobija se  $\alpha_1 = 0.066$ , pa je  $X_2 = [-0.797, 3.202]^T$

Treća iteracija:

$$\nabla f(X_2) = \begin{bmatrix} 0.060 \\ 0.064 \end{bmatrix}, X_3 = X_2 - \alpha_2 \begin{bmatrix} 0.060 \\ 0.064 \end{bmatrix} \rightarrow \alpha_2 = 0.040 \rightarrow X_3 = \begin{bmatrix} -0.8000299 \\ 3.20029 \end{bmatrix}$$

Dobijeno rešenje je veoma blisko tačnom:  $X^* = [-4/5, 16/5]^T = [-0.8, 3.2]^T$

## Bezuslovna optimizacija - funkcija više promenljivih



### Metode zasnovane na gradijentima

#### Metod najstrmijih gradijenata – Cauchy-jev metod

Nedostatak Cauchy-jeve metode je što se u svakoj iteraciji traži tačna veličina koraka u pravcu najstrmijeg pada, što može biti veoma složeno. Za rešavanje realnih problema, najčešće tačna vrednost koraka  $\alpha$  nije tako važna, već bi pronalaženje približne vrednosti bilo dovoljno dobro.

Ako se  $\alpha$ , traži na približan način u svakoj iteraciji proračuna, moraju biti ispunjeni određeni uslovi, kako izabrana vrednost ne bi bila prevelika ili premala.


Wolfe-ovi uslovi postavljaju ograničenja po pitanju vrednosti funkcije i prvog izvoda

$$\phi(\alpha) \leq \phi(0) + \varepsilon \cdot \phi'(0) \cdot \alpha$$

$$\phi'(\alpha) > (1 - \varepsilon) \cdot \phi'(0)$$

Gde je  $\varepsilon$  parametar koji uzima vrednost 0 do  $\frac{1}{2}$ .

Algoritam za pronalaženje prihvatljive vrednosti  $\alpha$ : krene se sa maksimalnom vrednošću i ispita se ispunjenost Wolfe-ovih uslova. Ako uslovi nisu ispunjeni, korak se redukuje množenjem sa faktorom koji je manji od 1 (npr. 0.9). Postupak se ponavlja dok uslovi nisu ispunjeni.



## Bezuslovna optimizacija - funkcija više promenljivih




### Metode zasnovane na gradijentima

Osnovni koraci optimizacionih metoda zasnovanih na gradijentima:

Definiše se početna tačka  $X_0$

$i = 0, 1, 2, \dots$

- proveriti konvergenciju u tački  $X_i$
- sračunati pravac pomeranja  $p_i$
- odrediti veličinu koraka pomeranja  $\alpha_i$
- odrediti položaj nove tačke  $X_{i+1} = X_i + \alpha_i p_i$



Sve metode zasnovane na gradijentima se razlikuju po tome na koji način se računaju pravac pomeranja i veličina koraka.

## Bezuslovna optimizacija - funkcija više promenljivih




### Metode bez gradijenata

Kada izvode funkcije nije moguće odrediti eksplicitno, jedna mogućnost je da se to uradi približno - numerički, a druga je da se proračun sprovede primenom neke metode koja ne zahteva poznavanje izvoda funkcije.

### Metoda Nelder-Mead-a:

Kod ove metode, za proračun se koristi skup rešenja, koji se pomera iz jedne iteracije u drugu. Brojnost ovog skupa je za jedan veći od broja nepoznatih, odnosno od dimenzija vektora  $X$ .

Iterativni skup  $P$ , koji ima  $n+1$  tačku u  $n$  dimenzionalnom prostoru, se naziva simplex. Kada je problem dvodimenzionalan, simpleks je trougao. U slučaju funkcije sa 3 nepoznate, simpleks je tetraedar.



## Bezuslovna optimizacija - funkcija više promenljivih



### Metode bez gradijenata

### Metoda Nelder-Mead-a

#### Osnovni koraci

Prvi korak je da se formira skup  $P$  koji se zatim sortira prema vrednosti kriterijumske funkcije  $f(X_i)$ :


$$P = \{X_0, \dots, X_n\}$$

$$f(X_0) < f(X_1) < \dots < f(X_n)$$

Zatim se nalazi centar simpleksa ali se prethodno izostavi tačka  $n+1$ , koja je najlošija tačka iz skupa  $P$ :

$$X_c = \frac{1}{n} \sum_{i=0}^{n-1} X_i$$

Na osnovu tačke  $X_c$  nalazi se tačka  $X_r$  koja predstavlja refleksiju najlošije tačke skupa  $P$ :  $X_r = X_c + \alpha(X_c - X_{n+1})$ , gde je  $\alpha$ , koeficijent veći od 0 (obično 1).



## Bezuslovna optimizacija - funkcija više promenljivih



### Metode bez gradijenata


#### Metoda Nelder-Mead-a

##### Osnovni koraci

Da li se nova tačka prihvata ili ne, zavisi od vrednosti funkcije  $f(X_r)$ :


- Ako je  $f(X_0) < f(X_r) < f(X_{n-1})$ , onda se najlošije rešenje  $X_n$  izbacuje iz skupa  $P$  a uvodi se novo rešenje  $X_r$ , u sortirani skup  $P$ , na mesto koje odgovara vrednosti funkcije  $f(X_r)$

- Ako je  $f(X_r) < f(X_0)$ , proba se sa daljom ekspanzijom simpleksa u tom pravcu, radi provere da li se vrednost funkcije može još više poboljšati:  $X_e = X_r + \alpha(X_r - X_c)$   
Ako je  $f(X_e) < f(X_r)$  prihvata se rešenje  $X_e$ , u protivnom se  $X_r$  koristi kao novo rešenje i uvodi se u skup  $P$  umesto najlošijeg rešenja  $X_n$ .



- Ako nema napredka  $f(X_r) > f(X_{n-1})$ , kontrakuje se simpleks tako što se najlošija tačka približava centru:  $X_k = X_n + \gamma(X_c - X_n)$

Gde  $\gamma$  uzima vrednost 0.5. Ako  $f(X_k) < f(X_n)$ ,  $X_k$  se koristi kao novo rešenje i uvodi se u skup  $P$  umesto najlošijeg rešenja  $X_n$ .



## Bezuslovna optimizacija - funkcija više promenljivih



### Metode bez gradijenata

#### Metoda Nelder-Mead-a

##### Osnovni koraci

Da li se nova tačka prihvata ili ne, zavisi od vrednosti funkcije  $f(X_r)$ :

- Ako nijedan od navedenih uslova nije ispunjen, ceo skup  $P$  se kontrakuje  $X_i = X_1 + \gamma(X_i - X_1)$  prema najboljem rešenju  $X_1$ :

